
Exploitation de dictionnaires électroniques pour la désambiguïsation sémantique lexicale

Caroline Brun — Bernard Jacquemin — Frédérique Segond

Xerox Research Centre Europe

6. chemin de Maupertuis

38240 Meylan

{Caroline.Brun,Bernard.Jacquemin,Frederique.Segond}@xrce.xerox.com

RÉSUMÉ. Cet article présente un système de désambiguïsation lexicale sémantique, conçu initialement pour l'anglais et à présent adapté à la désambiguïsation du français. La méthodologie développée repose sur l'utilisation d'un dictionnaire électronique comme un corpus sémantiquement étiqueté afin d'en extraire une base de règles de désambiguïsation sémantique. Ces règles permettent d'associer à un mot son sens compte tenu de son contexte. L'extraction et l'application des règles sont décrites en détail ainsi que l'évaluation du système. L'évaluation des résultats obtenus pour le français nous conduit à considérer un ensemble de perspectives concernant les ressources lexicales qui seraient les mieux adaptées à la tâche de désambiguïsation dans le cadre de cette méthodologie.

ABSTRACT. This paper presents a lexical disambiguation system, initially developed for English and now adapted to French. This system associates a word with its meaning in a given context using electronic dictionaries as semantically annotated corpora in order to extract semantic disambiguation rules. We describe the rule extraction and application process as well as the evaluation of the system. The results for French give us insight information on some possible improvements of the nature and content of lexical resources adapted for disambiguation in this framework.

MOTS-CLÉS : désambiguïsation sémantique lexicale, dictionnaire électronique, ressources lexicales.

KEYWORDS: lexical semantic disambiguation, electronic dictionary, lexical resources.

1. Introduction

Dans notre société, l'information – et plus particulièrement l'information électronique – prend chaque jour plus d'importance, et sa maîtrise est devenue la clef d'une certaine compétition, tant au niveau politique qu'économique ou scientifique. Dès lors, il est capital de pouvoir gérer les masses de données sans cesse plus abondantes qui sont mises à notre disposition. Dans cette perspective, diverses applications informatiques se révèlent indispensables pour qui veut prendre part à cet essor.

En effet, l'analyse approfondie du contenu des documents, la catégorisation de ce contenu, la recherche d'une information précise dans une base de données, ou encore la traduction assistée sont des outils indispensables pour avoir une compréhension globale et exacte des éléments jugés intéressants [VÉR 98b]. Or ces différents outils partagent un même postulat : il s'agit de pouvoir distinguer le sens adéquat de chaque mot en fonction du contexte dans lequel il apparaît. C'est là la tâche assignée aux systèmes de désambiguïsation sémantique lexicale.

Cette désignation du sens idoine des mots en contexte est également utile pour des logiciels plus discrets tels que les correcteurs orthographiques, aussi bien ceux des traitements de texte que ceux qui permettent aux systèmes de dictée vocale d'approcher une orthographe correcte.

Un désambiguïsateur sémantique lexical est un système qui permet de sélectionner dans une liste généralement prédéfinie la signification que possède un mot polysémique en fonction de son contexte d'apparition. Pour ce faire, plusieurs méthodes existent qui tantôt sont concurrentes, tantôt s'allient pour parvenir au meilleur résultat. Deux types d'approches coexistent : les modèles statistiques se basent essentiellement sur l'étude de corpus sémantiquement étiquetés pour déterminer le sens d'un mot polysémique en fonction de son environnement lexical ; les approches centrées sur les bases de connaissances consistent à exploiter des ressources lexico-sémantiques telles que les dictionnaires, lexiques ou thesaurus. Généralement, toutes utilisent l'environnement lexical des mots polysémiques.

La tâche de la désambiguïsation sémantique requiert donc énormément de ressources lexicales sous la forme de corpus sémantiquement étiquetés, de dictionnaires, d'ontologies ou de réseaux sémantiques. Or la carence de ces ressources est omniprésente pour toutes les langues, excepté l'anglais qui dispose de thesaurus comme le Roget, d'ontologies sous formes de réseaux (WordNet, Cyc), de corpus étiquetés (Brown, Hector).

Au cours des dernières années, de louables efforts ont été menés pour que d'autres langues rattrapent un peu du retard qu'elles ont pris dans la construction de ressources lexico-sémantiques, notamment avec l'initiative de RomansEval¹ qui a permis la constitution de corpus sémantiquement étiquetés pour le français et l'italien, ainsi qu'avec le consortium EuroWordNet², chargé de construire un réseau sémantique multilingue

1. <http://www.lpl.univ-aix.fr/projects/romanseval/>

2. <http://www.hum.uva.nl/ewn/>

correspondant à son prédécesseur anglais WordNet, et cela pour sept autres langues (français, néerlandais, espagnol, italien, allemand, tchèque et estonien). Ces initiatives restent cependant ponctuelles et appellent des mises en œuvre plus importantes ([VIE 99]).

Par contre, les dictionnaires électroniques se sont multipliés ces derniers temps, avec l'émergence des langages à structure balisante qui permettent d'organiser rationnellement l'information contenue. Ainsi, les dictionnaires, disponibles dans de nombreuses langues dans des formats SGML ou XML, autorisent une exploitation précise des données qu'ils contiennent et du fait de ces formats, présentent une cohérence accrue par rapport à leurs prédécesseurs papier.

Cet article décrit un système de désambiguïsation lexicale sémantique qui repose sur l'utilisation d'un dictionnaire électronique et s'inscrit dans la continuité de précédents travaux dans ce domaine³. Nous avons en effet décidé de tirer parti de la structure précise et de la cohérence accrue de ce nouveau type de ressource. Notre système associe à un mot un des sens que propose le dictionnaire en fonction de son contexte lexico-syntaxique dans son document d'apparition. Nous exposons tout d'abord des considérations sur l'utilisation de dictionnaires dans le contexte de la désambiguïsation lexicale sémantique et décrivons en détail la ressource que nous avons décidé d'exploiter.

Nous expliquons ensuite le fonctionnement du système, c'est-à-dire les processus d'extraction et d'application des règles.

Enfin, et c'est ce sur quoi nous souhaitons insister dans cet article, l'évaluation du système conduite pour le français nous amène à réfléchir sur le type de ressource lexicale qui serait appropriée pour mener à bien la tâche de désambiguïsation.

2. Dictionnaires

2.1. *Dictionnaires et désambiguïsation lexicale sémantique*

Comme nous l'avons indiqué dans l'introduction, notre système de désambiguïsation sémantique repose sur l'exploitation d'un dictionnaire électronique. Les dictionnaires constituent des ressources particulièrement intéressantes dans ce cadre. En effet, [LES 86], [WIL 90] et [WIL 98] associent à chaque acception d'un mot le vocabulaire de sa définition dans un dictionnaire et exploitent ce vocabulaire pour évaluer le contexte dans un document et lui attribuer le sens correspondant. [VÉR 90] enrichissent cette méthode en créant un réseau neuronal où chaque mot est relié à ses différents sens et où chaque sens est relié aux mots de sa définition, à leur tour reliés à leurs différentes acceptions. Certains (notamment [GUT 91] et [COW 92]) développent cette même ap-

3. [SEG 00b] décrit une exploitation des collocations et schémas de sous-catégorisation d'un dictionnaire, [BRU 01] présente un système équivalent à celui décrit dans cet article et son évaluation pour l'anglais, [BRU 00] détaille l'architecture logicielle de ce système.

proche en s'écartant de la contrainte lexicale : ils tirent parti d'une information supplémentaire de la version électronique du *Longman Dictionary of contemporary English* [PRO 78], en particulier les primitives sémantiques classifiant les sens du lexique, et les restrictions portant sur les noms, les adjectifs et les arguments des verbes en fonction de leurs acceptions. Plus récemment, [ELL 00] et [LIT 00] ont entrepris d'utiliser l'information lexicale, syntaxique et sémantique du dictionnaire Hector de SensEval pour effectuer un filtrage de sens par élimination des acceptions inappropriées au contexte. Enfin, divers systèmes utilisent l'architecture hiérarchique de WordNet, principalement les différents sens définis ainsi que les relations sémantiques établies entre les nœuds, pour choisir celui des sens qui, en fonction de la structure de WordNet, se rapproche le plus de son contexte ([SUS 93, RES 95, CAR 00, HAW 00]).

Notre système de désambiguïsation sémantique repose sur l'exploitation d'un dictionnaire électronique. Les dictionnaires constituent des ressources particulièrement intéressantes dans ce cadre. En effet, [LES 86], [WIL 90] et [WIL 98] utilisent les définitions d'un dictionnaire pour évaluer le contexte d'un mot et lui attribuer un sens, tandis que [VÉR 90] enrichissent cette méthode en y adjoignant un réseau neuronal. D'autres exploitent une autre information, notamment les primitives de la version électronique du *Longman Dictionary of contemporary English* [PRO 78] (notamment [GUT 91] et [COW 92]). Plus récemment, [ELL 00] et [LIT 00] ont entrepris d'utiliser l'information du dictionnaire Hector de SensEval pour filtrer et réduire l'ensemble des sens possibles des mots en contexte. Divers systèmes exploitent également l'architecture hiérarchique de WordNet pour définir une base de connaissances ([SUS 93, RES 95, CAR 00, HAW 00]).

Le choix d'une méthode basée sur l'utilisation d'un dictionnaire comme ressource sémantique associée repose sur une série d'arguments convaincants : un dictionnaire est conçu et organisé autour de la notion de sens et de mot, et constitue de ce fait un outil parfaitement adapté pour effectuer une sélection du sens contextuel d'un mot. D'autre part, le découpage des entrées polysémiques en différents sens est extrêmement rigoureux, ce qui implique une grande précision de cette information. Dans cette perspective, on peut considérer le dictionnaire comme un corpus sémantiquement étiqueté particulièrement fiable.

Le dictionnaire que nous avons sélectionné, le *Oxford-Hachette French Dictionary* (OHFD, [COR 94]), contient de très nombreux exemples représentatifs du sens qu'ils illustrent, ainsi qu'une riche information sur les collocations typiques d'un sens. D'autres informations comme les étiquettes morpho-syntaxiques sont également très précieuses dans le cadre de notre méthode. Le codage SGML dans lequel ce dictionnaire a été conçu permet d'appréhender aisément cette information pour la traiter, et il permet, grâce à une définition de type de document (DTD) stricte, d'identifier un format de présentation de l'information cohérent et aisément exploitable ([IDE 98]).

De plus, ce dictionnaire est un ouvrage général, qui reprend donc un maximum du vocabulaire courant et de ses différentes significations. Il s'agit d'un atout majeur pour un système de désambiguïsation sémantique car il se rapproche ainsi d'une certaine exhaustivité, tant au niveau des mots à désambiguïser qu'au niveau des possibilités de

sélection. La méthode de constitution du dictionnaire présente aussi un intérêt qu'il ne faut pas négliger, puisque c'est à partir d'un corpus que les sens ont été ordonnés dans chaque entrée : selon le corpus utilisé, une signification qui se présente devant une autre a statistiquement plus de chances d'apparaître que le sens suivant. On verra dans la description de la méthode que ce détail peut avoir son importance.

Enfin, c'est un dictionnaire bilingue, ce qui présente évidemment des avantages pour les applications de type multilingue, et notamment les logiciels d'aide à la traduction. Mais un dictionnaire bilingue contient certaines particularités structurales intéressantes, essentiellement un découpage en sens plus systématique dans chaque langue du fait des impératifs de correspondance avec l'autre langue. Il s'ensuit une granularité plus fine, ainsi qu'un nombre d'exemples significatifs plus important.

Bien entendu, la méthodologie proposée ici ne nécessite pas impérativement l'utilisation d'un dictionnaire bilingue. Elle peut aussi bien s'appliquer en utilisant une ressource lexicale monolingue ou même spécialisée si on veut se concentrer sur un domaine précis. Toutefois, la ressource retenue devra répondre à certaines exigences : il s'agit essentiellement de la qualité des exemples et des collocations, qui devront être représentatifs d'un sens auquel ils seront reliés explicitement. En effet, c'est essentiellement de ces informations que dépend la qualité des règles de désambiguïsation, comme on le verra dans la description du système.

2.2. Description du dictionnaire OHFD

Le dictionnaire OHFD comporte 47 539 entrées pour la partie anglais-français et 38 944 entrées pour la partie français-anglais. Le contenu du OHFD est découpé en cinq niveaux imbriqués. Les vedettes correspondent aux entrées du dictionnaire (1^{er} niveau). Puis chaque entrée est découpée en parties, selon les parties du discours qui peuvent être celles de la vedette (2^{ème} niveau). Chaque partie du discours est ensuite découpée selon les sens que peut prendre la vedette (3^{ème} niveau ou S1). Enfin des indicateurs sémantiques (4^{ème} niveau ou S2) et/ou des indicateurs de collocations et des exemples (5^{ème} niveau ou S3) pointent sur des équivalents différents.

Les éléments sont marqués par leur fonction (vedette, label, collocation, exemple, etc.). Les étiquettes *sémantiques* du dictionnaire qui permettent à l'utilisateur de trouver l'équivalent qui convient sont de trois types⁴ :

- les labels (balisés avec <la>) : ce sont des marqueurs de registre/style (journalistique, familier, etc.), de langue (anglais américain, écossais, etc.) ou de domaine (architecture, médecine, zoologie, etc.) ;
- les indicateurs (balisés avec <ic>) : ce sont des notes explicatives qui précisent l'usage de l'entrée (par exemple, pour l'entrée **chien**, l'indicateur *de fusil* pointe sur « hammer »).

4. Ces étiquettes sont décrites dans [AKR 92].

– les collocations (balisées avec <co>) : ce sont les collocations habituelles (sujet ou objet pour les verbes, nom modifié pour les adjectifs).

– les exemples : ce sont des exemples d'utilisation de la vedette, qui illustrent le contexte syntaxique et sémantique d'un sens donné attaché à la vedette. Ces exemples peuvent être de différents types :

- exemples de mot *composé* (balisés <lc>),
- exemples *idiomatiques* , (balisés),
- exemples *phrasal verb* (pour l'anglais), (balisés <lv>),
- exemples de *structure*, (balisés <ls>),
- exemples d'*usage*, (balisés <lu>),
- exemples *généraux*, (balisés <le>).

C'est l'information syntaxico-sémantique contenue dans les indicateurs de collocations et les exemples qui est exploitée par le système de désambiguïsation que nous avons conçu.

La figure Figure 1 représente la version « papier » de l'entrée lexicale du mot *abandonner* dans le OHFD.

3. Description du système de désambiguïsation lexicale sémantique

3.1. Architecture

L'architecture du système de désambiguïsation lexicale sémantique que nous avons développé est centrée sur l'utilisation du dictionnaire OHFD utilisé comme un corpus sémantiquement étiqueté. Comme nous l'avons décrit précédemment, pour chacun des mots du dictionnaire, les différents sens possibles sont distingués et illustrés par des exemples d'utilisation, des indicateurs de collocations, des indicateurs sémantiques etc. À partir de ces informations attachées à un sens donné d'un mot, nous extrayons des règles de désambiguïsation sémantique en utilisant un « shallow parser », qui en extrait les relations fonctionnelles ainsi qu'un réseau sémantique. Ce dernier permet d'associer des étiquettes sémantiques aux arguments de relations fonctionnelles. Ces règles prennent donc en compte le contexte illustratif du sens du mot pour lequel elles sont construites. Une fois la base de règles extraite pour l'ensemble du dictionnaire, elle est utilisable, via un algorithme spécifique d'application, pour la désambiguïsation des mots apparaissant dans du texte libre : les phrases du texte sont analysées en utilisant le même shallow parser et les relations fonctionnelles en sont extraites. Pour chacun des mots entrant en jeu dans une relation fonctionnelle on recherche dans la base de règle si l'une d'entre elles peut s'appliquer (la stratégie de sélection est détaillée par la suite). Si c'est le cas, on peut associer au mot le numéro de sens correspondant dans le dictionnaire.

abandonner /abA+ dOne/ 1

I vtr

1 (*renoncer à*) to abandon, to give up [*projet, théorie, activité, espoir*]; to give up [*habitude*]; to give up, to forsake *sout* [*confort, sécurité*]; *Scol* to drop [*matière*]; *~les recherches* to give up the search; *~la cigarette/l'alcool* to give up smoking/drinking; *les médecins l'ont abandonné* the doctors have given up on him; *je peignais, mais j'ai abandonné* I used to paint, but I gave it up; *c'est trop dur, j'abandonne* it's too hard, I give up; *~la partie or lutte* to throw in the towel;

2 (*céder*) to give ou relinquish *sout* [*bien*] (*à qn* to sb); to hand [sth] over [*gestion*] (*à qn* to sb); *je vous abandonne le soin d'expliquer* I'm leaving it to you to explain; *elle lui abandonna sa main* she let him take her hand;

3 (*se retirer de*) to give up [*fonction*]; *Sport (avant l'épreuve)* to withdraw; (*pendant l'épreuve*) to retire; *forcé d'~la course* forced to withdraw from the race; *~ses études* to give up one's studies;

4 (*quitter*) to leave [*personne, lieu*]; to abandon [*véhicule, objet, navire*]; *~Paris pour Nice* to leave Paris for Nice; *il s'enfuit, abandonnant son butin* he abandoned the loot and fled; *~la ville pour la campagne* to move out of town to live in the country; *~le terrain lit* to flee; *fig* to give up;

5 (*délaisser*) to abandon, to forsake *sout* [*enfant, famille*]; to abandon [*animal*]; to desert [*foyer, épouse, poste, cause, parti*];

6 (*livrer*) *~qch à* to leave ou abandon sth to; *~un jardin aux orties* to abandon a garden to the nettles; *~qn à son sort* to leave ou abandon sb to his/her fate;

7 (*faire défaut*) [*courage, chance*] to desert [*personne*]; *mes forces m'abandonnent* my strength is failing me;

8 (*lâcher*) to let go of [*outil, rênes*];

9 *Ordinat* to abort .

II s'abandonner vpr

1 (*se confier*) to let oneself go;

2 (*se détendre*) to let oneself go; *s'~dans les bras* de qn to sink into sb's arms;

3 (*se laisser aller*) *s'~à la passion/au désespoir* to give oneself up ou to abandon

oneself to passion/to despair; *s'~au plaisir de* to lose oneself in the pleasure of; *s'~au sommeil* to let oneself drift off to sleep;

4 (*se donner sexuellement*) [*femme*] to give oneself (*à* to).

Figure 1 – Entrée de **abandonner** dans le Oxford-Hachette




Figure 2 – Architecture du système

L'architecture générale du système est illustrée sur la figure Figure 2. Ce système, initialement développé pour la désambiguïsation sémantique de l'anglais ([BRU 01, BRU 00]), est maintenant adapté au cas du français, ce que nous décrivons dans cet article.

3.2. *Shallow parser*

Les relations syntaxiques de type sujet, objet, modifieur, etc., utilisées à la fois dans les phases d'extractions et d'application des règles sémantiques, sont extraites à l'aide d'un analyseur syntaxique de surface (« shallow parser »), IFSP, [AiT 97]. La technologie de IFSP est fondée sur des transducteurs d'états finis appliqués en cascade pour marquer les syntagmes noyaux (« chunks ») et extraire les relations syntaxiques entre syntagmes. Ces transducteurs sont appliqués après une phase d'analyse

présyntaxique : segmentation, analyse morphologique et désambiguïsation des parties du discours.

Voici un exemple d'analyse donnée par IFSP pour une phrase tirée du journal *Le Monde* :

Un côté documentaire – son réalisateur Marc Levin y a fait ses premières armes – et un côté fiction qui nous fait penser qu'à chaque fois que Slam s'aventure sur un terrain, il ne le fait qu'en intrus, en abandonnant les protagonistes à leur sort, en oubliant plus ou moins consciemment des règles élémentaires de mise en scène.

[NP Un côté NP]/N [AP documentaire AP] - [SC [NP
son réalisateur
Marc_Levin NP]/SUBJ :v y a fait SC] [NP ses
premières armes NP]/OBJ
- et [NP un côté NP]/OBJ [NP fiction NP]/N [SC [NP
qui NP]/SUBJ
:v nous fait SC] [v penser v] [SC qu' [SC [PP à
chaque_fois_que Slam PP]
:v s' aventure SC] [PP sur un terrain PP] , [NP il
NP]/SUBJ :v
ne le fait SC] qu' en [AP intrus AP] , [v en
abandonnant v]
[NP les protagonistes NP]/OBJ [PP à leur sort PP] ,
[v en oubliant v]
plus_ou_moins consciemment [PP des règles PP] [AP
élémentaires AP]
[PP de mise_en_scène PP] .

SUBJ(il,faire)
RELSUBJ(fiction,penser)
DOBJ(abandonner,protagoniste)
DOBJ(faire,arme)
VMODOBJ(oublier,de=le,règle)
VMODOBJ(aventurer,sur,terrain)
ADJ(réalisateur,Marc_Levin)
PADJ(côté,documentaire)
NNPREP(règle,de,mise_en_scène)

SUBJ(Marc_Levin,faire)
RELSUBJ(fiction,faire)
DOBJ(faire,côté)
VMODOBJ(oublier,de,mise_en_scène)
VMODOBJ(abandonner,à,sort)
ADJ(premier,arme)
PADJ(règle,élémentaire)
NN(côté,fiction)
NNPREP(protagoniste,à,sort)

3.3. Extraction des règles de désambiguïsation du dictionnaire

Dans un premier temps, pour chacune des entrées du dictionnaire, un numéro de sens (Snum) est associé à chacune des différentes catégories sémantiques du dictionnaire. Ces numéros de sens sont utilisés comme des étiquettes sémantiques lors de l'application des règles puisqu'ils désignent de façon déterministe un sens spécifique

d'une entrée donnée. Dans le cas du OHFD, la numérotation consiste à concaténer le numéro désignant la partie syntaxique S1 (I, II, ...), et le numéro désignant la partie sémantique S2 (1, 2, ...).

Les règles extraites sont de deux types (cf. Ginger I, [DIN 98, DIN 00]) :

– au niveau du mot (règles lexicales), ce sont des règles qui s'appliquent sur la base du contexte lexical du mot à désambiguïser ;

– au niveau des classes sémantiques (règles sémantiques), ce sont des règles qui s'appliquent sur la base du contexte sémantique du mot à désambiguïser et qui sont construites en utilisant les catégories sémantiques d'un dictionnaire ou d'un thésaurus.

La base de règles est construite de la façon suivante : pour chaque sens Snum d'une entrée, les différents exemples sont analysés syntaxiquement et les relations en sont extraites au moyen de IFSP. Si une relation met en jeu l'entrée elle-même, une première règle de désambiguïsation est construite :

Si l'entrée X apparaît dans la relation syntaxique REL(X,Y), alors elle peut être désambiguïlée avec son sens Snum.

Il s'agit d'une règle au niveau d'un mot puisqu'elle considère le contexte lexical.

Par exemple, dans l'entrée de *abandonner* (cf. figure Figure 1), un exemple de type général illustre le sens I.6 de la section *vtr* : *abandonner qn à son sort*.

Le shallow parser extrait les relations suivantes de cet exemple : DOBJ(*abandonner,quelqu'un*)⁵ et VMODOBJ(*abandonner,à,sort*)⁶, ce qui nous permet de construire les règles lexicales :

*abandonner*_(I.1,I.2,I.3,I.4,I.5,I.6,I.7,I.8,I.9,II.1,II.2,II.3,II.4) :

DOBJ(*abandonner,quelqu'un*) => I.6

*abandonner*_(I.1,I.2,I.3,I.4,I.5,I.6,I.7,I.8,I.9,II.1,II.2,II.3,II.4) :

VMODOBJ(*abandonner,à,sort*) => I.6

ce qu'on peut paraphraser ainsi : si le mot *abandonner*, ambigu dans le OHFD entre les sens (I.1,I.2,I.3,I.4,I.5,I.6,I.7,I.8,I.9,II.1,II.2,II.3,II.4), apparaît dans les relations DOBJ(*abandonner,quelqu'un*) et/ou VMODOBJ(*abandonner,à,sort*), alors il peut être désambiguïlé avec le sens I.6.

On construit des règles semblables en utilisant les collocations associées aux entrées lexicales. Le type de la relation mise en jeu entre une collocation et l'entrée lexicale qui lui correspond est directement codée dans le dictionnaire. Par exemple, dans une entrée pour un verbe, une collocation est de type sujet ou objet, cette information étant présente sous forme d'une balise SGML. On peut donc extraire les règles

5. DOBJ = complément d'objet direct.

6. VMODOBJ = complément indirect modifieur du verbe.

issues d'information de type collocation directement à partir des entrées, sans utiliser IFSP.

Dans un deuxième temps, des classes sémantiques sont utilisées afin d'élargir le champ d'application des règles déjà construites. Pour chacune de ces règles, l'argument Y de la relation fonctionnelle est remplacé par l'ensemble des classes sémantiques auxquelles il appartient :

Si l'entrée X apparaît dans la relation syntaxique REL(X,classe_d'ambiguïté(Y)), alors elle peut être désambiguïlée avec son sens Snum.

Ce sont des règles au niveau des classes, puisqu'elles prennent en compte le contexte sémantique du mot à désambiguïser.

Dans le cas du désambiguïsateur réalisé pour l'anglais ([BRU 01, BRU 00]), les classes utilisées étaient les classes de plus haut niveau données par WordNet. Pour l'adaptation du système au français, s'est posé le problème du choix de l'ontologie. Il n'existe actuellement aucune ressource francophone comparable à WordNet malgré l'initiative du consortium EuroWordNet qui vise à la construction de réseaux sémantiques équivalents à WordNet en diverses langues européennes, dont le français. En effet, les objectifs de cette entreprise ne visaient pas à décrire l'ensemble du lexique, et le vocabulaire restreint du réseau ne permet pas son exploitation dans le cadre d'une application générale. Or, nous disposons d'un dictionnaire morpho-syntaxico-sémantique, le dictionnaire AlethDic⁷ ([Gsi94]), dont nous pouvions exploiter l'information assez directement.

Le contenu du dictionnaire électronique AlethDic est une compilation de différents projets lexicographiques menés auparavant par Gsi-Erli⁸. La fusion de plusieurs dictionnaires préexistants provenant d'horizons différents a généré une grande variété de vocabulaire.

AlethDic est une base lexicale (environ 55 000 entrées) multicouche dont chacune des couches correspond à un niveau d'information linguistique : morphologique, syntaxique, sémantique. Ce type d'architecture correspond aux recommandations GENELEX ([GENELEX 94]) édictées dans le cadre du projet EUREKA ([MEN 93]) qui fait correspondre à chaque entrée lexicale ses caractéristiques morphologiques, qu'elles soient atomiques ou multiples. À chacune des unités morphologiques correspond ensuite son ou ses pendants dans la couche syntaxique. Enfin, chaque entité lexicosyntaxique est associée à une ou plusieurs composantes sémantiques.

Dans le cadre de la désambiguïsation lexicale sémantique, c'est la couche sémantique qui retient notre attention. Elle limite ses informations aux noms, adjectifs et adverbes. Pour ces catégories, l'information sémantique est de deux types : le premier est la description de chaque sens de l'unité lexicale à l'aide d'une classe sémantique

7. Il s'agit de la version 1.5.5 datant de 1994.

8. Lexiquet à présent.

(3 catégories pour les adjectifs, 8 pour les adverbes et 71 pour les noms) qui peut être accompagnée d'un ou plusieurs traits ; le second correspond aux relations entre les unités lexicales (antonymie, synonymie, etc.). C'est la répartition des entrées en différentes catégories sémantiques que nous utilisons pour la désambiguïsation.

En utilisant cette ressource, les règles sémantiques extraites sont les suivantes, l'argument remplacé par la liste des classes auxquelles il appartient étant respectivement *quelqu'un* et *sort* :

*abandonner*_(I.1,I.2,I.3,I.4,I.5,I.6,I.7,I.8,I.9,II.1,II.2,II.3,II.4) :

DOBJ(*abandonner*,HUMAIN) => I.6

*abandonner*_(I.1,I.2,I.3,I.4,I.5,I.6,I.7,I.8,I.9,II.1,II.2,II.3,II.4) :

VMOBJ(*abandonner*,à,EVENEMENT/ABSTRAIT) => I.6

ce qu'on peut paraphraser ainsi : si le mot *abandonner*, ambigu dans le OHFD entre les sens (I.1,I.2,I.3,I.4,I.5,I.6,I.7,I.8,I.9,II.1,II.2,II.3,II.4), apparaît dans une relation DOBJ avec un mot appartenant à la classe sémantique HUMAIN et/ou dans une relation VMOBJ avec un mot appartenant à la classe sémantique EVENEMENT OU ABSTRAIT, alors il peut être désambiguïsé avec le sens I.6.

Pour les deux sortes de règles, le type de l'exemple (<lc>,<le>,,<lu>,<lv> ou <co> s'il s'agit d'une collocation) est encodé dans la règle, cette information étant utile lors de l'application des règles (cf. infra). Chacun des exemples et collocations attachés à un S2 donné possède également un numéro, S3, que nous encodons également.

Toutes les entrées du dictionnaire sont ainsi traitées, ce qui permet la création d'une large base de règles de désambiguïsation indexée sur chaque mot (environ 217 500 règles pour le français et 270 000 pour l'anglais⁹). Cette base de règles, extraite une fois pour toutes du dictionnaire, est alors exploitable par le système pour effectuer la tâche de désambiguïsation.

3.4. Algorithme d'application

La base de règles est utilisée par un programme d'application de règles qui permet la désambiguïsation des mots d'un corpus quelconque. Lorsque plusieurs règles sont en concurrence pour un mot donné, une stratégie de sélection par type de règle est appliquée. Dans le cas opposé où aucune règle ne s'applique, le résultat donné par défaut est le premier sens du OHFD (correspondant à la partie du discours du mot).

9. Cette différence numérique est essentiellement due au fait que nous ne disposons pas de classes sémantiques pour les verbes.

Comme ce dictionnaire a été construit en utilisant les fréquences des mots en corpus, le sens le plus fréquent apparaît en premier.

Tout d’abord la phrase contenant le mot à désambiguïser est analysée syntaxiquement et les relations syntaxiques en sont extraites. L’ensemble des relations mettant en jeu le mot à désambiguïser sont candidates pour être comparées aux règles de désambiguïsation.

On cherche en premier lieu les règles lexicales qui peuvent s’appliquer, c’est-à-dire celles dont les arguments sont exactement les mêmes, aux variations morphologique près¹⁰.

Si une seule règle est applicable, elle est sélectionnée et son numéro de sens est associé au mot cible.

Si aucune règle lexicale n’est directement applicable, on cherche si l’on peut trouver des équivalences entre règles et contexte syntaxique. Par exemple, si une règle met en jeu une relation de type sujet passif SUBJPASS(A,B), elle est équivalente à une règle de type objet direct DOBJ(B,A), et vice versa. Un ensemble de relations syntaxiques sont équivalentes, comme sujet SUBJ(A,B), sujet de relative RELSUBJ(A,B) et agent passif PAGENT(B,A), ou encore adjectif ADJ(A,B) et attribut ATTR(B,A).

Au contraire, si plusieurs règles lexicales peuvent s’appliquer en concurrence, la sélection se fait en se fondant sur le type de la règle, c’est-à-dire le type de l’information à partir de laquelle elle a été créée. Ainsi, les règles sont pondérées dans l’ordre d’application suivant :

- règle issue de *collocation* (<co>),
- règle issue d’exemple de type *composé* (<lc>),
- règle issue d’exemple de type *idiomatique* (),
- règle issue d’exemple de type *phrasal verb* (dans le cas de l’anglais) (<lv>),
- règle issue d’exemple de type *usage* (<lu>),
- règle issue d’exemple de type *général* (<le>).

Cette stratégie repose sur les distinctions linguistiques faites par les lexicographes au moment de la construction du dictionnaire et prend en compte la « typicité » des informations attachées aux distinctions sémantiques des mots : le choix de la règle à appliquer est réalisé en les ordonnant de la plus typique à la plus générale.

Cherchons à désambiguïser le mot *abandonner* dans la phrase suivante :

Un côté documentaire – son réalisateur Marc Levin y a fait ses premières armes – et un côté fiction qui nous fait penser qu’à chaque fois que Slam s’aventure sur un terrain, il ne le fait qu’en intrus, en abandonnant les protagonistes à leur sort, en oubliant plus ou moins consciemment des règles élémentaires de mise en scène.

10. Les arguments des relations extraites par IFSP sont lemmatisés.

Les relations syntaxiques extraites par le shallow parser et mettant en jeu le mot *abandonner* sont :

DOBJ(*abandonner*, protagoniste)
VMODOBJ(*abandonner*, à, sort)

Ici, (au moins) une règle lexicale s'applique directement :

*abandonner*_(I.1, I.2, I.3, I.4, I.5, I.6, I.7, I.8, I.9, II.1, II.2, II.3, II.4) :

VMODOBJ(*abandonner*, à, sort) => I.6

Le mot *abandonner* peut donc être désambiguïsé avec le sens I.6 du OHFD, qui a le sens général de *livrer*. Comme le système dispose du numéro d'exemple (S3), il propose la traduction correspondante, ici *to leave ou abandon sb to his/her fate*.

Remarquons que plusieurs règles peuvent désigner le même numéro de sens : c'est le cas en particulier lorsque l'on peut extraire plusieurs règles d'un exemple du dictionnaire et que l'on retrouve exactement le même contexte dans la phrase à traiter. La stratégie d'application prend en compte cette possibilité en additionnant les poids de ces règles, ce qui équivaut à faire prévaloir les conjonctions logiques de règles.

Si aucune règle lexicale n'est susceptible de s'appliquer, le système explore alors la liste des règles sémantiques. Afin d'effectuer la sélection, la distance entre la liste L1 des classes sémantiques d'une règle potentielle et la liste L2 des classes sémantiques associées à l'argument de la relation en contexte est calculée comme suit :

$$d = \frac{(CARD(UNION(L1, L2)) - CARD(INTER(L1, L2)))}{CARD(UNION(L1, L2))}$$

Cette distance peut varier de 0 à 1, 0 lorsque la totalité des classes est commune, 1 lorsque l'intersection est vide : la règle choisie est celle qui présente une distance minimale. Dans le cas où plusieurs règles présentent cette distance minimale, la stratégie de sélection en fonction du type est à nouveau appliquée.

Cherchons à nouveau à désambiguïser *abandonner* dans l'exemple suivant :

Sans tribune et sans reconnaissance légale, M. Gustavo Arcos, secrétaire général du Comité pour les droits de l'homme, s'efforce, sous la seule protection des ambassades, de convaincre les jeunes de ne pas abandonner le pays.

Une relation syntaxique mettant en jeu le mot *abandonner* est extraite par le shallow parser :

DOBJ(*abandonner*, pays)

Dans le cas de cet exemple, il n'y a pas de règle lexicale qui puisse s'appliquer. Par contre, les classes sémantiques de *pays* étant ESPACE_LOCATIF, GEO, HUMAN_COLLECTIF, une règle sémantique, extraite du sens I.4 de *abandonner* dans le OHFD, est applicable. Cette règle correspond à la collocation objet *lieu* de *abandonner*, les classes sémantiques attachées à *lieu* étant : ENTITE, ESPACE_LOCATIF, ANIMAL :

*abandonner*_(I.1,I.2,I.3,I.4,I.5,I.6,I.7,I.8,I.9,II.1,II.2,II.3,II.4) :

DOBJ(*abandonner*,ENTITE/ESPACE_LOCATIF/ANIMAL) => I.4

Cette règle s'applique avec une distance de 0.8 par rapport au contexte. Le mot *abandonner* peut donc être désambiguïsé avec le sens I.4 du OHFD, dont le sens général est *quitter* et la traduction *to leave*¹¹.

Il peut arriver que plusieurs règles potentiellement applicables désignent le même numéro de sens. La stratégie de sélection prend en compte cette possibilité en multipliant entre elles les distances de ces règles ce qui a pour effet de produire une distance « globale » diminuée, et donc une plus grande probabilité de sélection. Le système met donc l'accent sur la redondance sémantique exhibée par le contexte du mot (conjonction de règles).

3.5. *Implantation*

Le système présenté est implanté dans le cadre d'une application client/serveur dédiée à l'analyse linguistique. L'extracteur de règles est un client qui utilise les différentes fonctionnalités du serveur (principalement analyse syntaxique par le shallow parser et consultation du dictionnaire). Le programme d'application des règles est implanté comme un service spécifique de consultation du dictionnaire : la consultation sémantique du dictionnaire. Lorsqu'un mot est désambiguïsé, l'entrée correspondante est réordonnée en fonction du sens qui lui est associé, ce sens étant présenté en premier à l'utilisateur. Si toutefois la méthode ne s'applique pas, le premier sens proposé est le sens par défaut donné par le OHFD. Le système, qui traite tous les mots d'un corpus quelconque, est robuste et capable d'analyser de larges corpus.

4. *Évaluation des résultats*

4.1. *Évaluation*

Le système présenté dans cet article a précédemment été évalué pour l'anglais [BRU 00], dans le corpus de SenseEval [KIL 99]. Nous souhaitons présenter ici les ré-

11. Dans le cas de règles sémantiques, il nous a paru préférable de donner les sens et traduction générales.

sultats obtenus récemment pour la désambiguïsation du français¹². L'évaluation des résultats ne fait pas la distinction entre les erreurs propres au système de désambiguïsation sémantique et les outils qu'il utilise dans sa chaîne d'analyse. Nous désirions en effet connaître les résultats réels de notre système plutôt que le résultat théorique lié exclusivement à la désambiguïsation lexicale sémantique.

Le but de cette évaluation est double : d'une part identifier les problèmes liés à la méthode et aux ressources utilisées, d'autre part, constituer un corpus sémantiquement étiqueté avec les sens du OHFD. Le découpage d'un mot en sens pose souvent des problèmes que les lexicographes discutent entre eux. Dans l'utilisation que nous faisons d'un dictionnaire, nous avons opté pour la confiance dans le choix des concepteurs des ressources utilisées [VÉR 98a], [SEG 00a]. L'évaluation du système pour le français est conduite en utilisant pour corpus un extrait du journal *Le Monde* d'environ 850 phrases¹³. Les mots qui nous intéressent lors de cette évaluation sont les noms, les adjectifs et les verbes, ce qui représente un total d'environ 14 000 mots. Nous obtenons les résultats de précision et couverture présentés sur le tableau 1. Ces résultats sont donnés en fonction des parties du discours ainsi que du type de règle (lexicale ou sémantique).

Cat.	Préc. Règles Lex.	Préc. Règles Sém.	Préc. toutes Règles	Couverture Règles Lex.	Couverture Règles Sém.	Couverture toutes Règles
Noms	.88	.48	.68	.24	.14	.38
Verbes	.97	.50	.58	.08	.19	.27
Adj.	1	.51	.68	.23	.23	.46
Total	.90	.50	.65	.19	.16	.35

Tableau 1 – Résultats de l'évaluation pour le français

Plusieurs remarques peuvent être faites concernant ces résultats :

1) D'une manière générale, la précision globale obtenue par le système (.65) dans le cas du français est nettement plus faible que celle obtenue pour l'anglais (il s'agissait d'environ .80). La précision fournie par les règles lexicales étant tout à fait comparable (.90 dans les deux cas), on constate donc que le problème provient principalement des règles sémantiques dont la précision est relativement médiocre pour le français (.50 contre environ .70 pour l'anglais).

Il semble donc que l'utilisation des classes données dans WordNet est plus adaptée à la tâche de désambiguïsation que celles proposées par le dictionnaire AlethDic.

En particulier, l'information lexico-sémantique d'AlethDic est constituée de divers lexiques disparates préexistants qui sont souvent spécifiques à un domaine d'application. Or, si le domaine marque parfois explicitement la signification spécialisée d'un mot, ce n'est pas une constante.

12. Un système préexistant pour le français a déjà été évalué dans [LUX 99].

13. Il s'agit d'une évaluation partielle, le corpus choisi comptant au total environ 3 000 phrases.

Le mot *condition* dispose des classes¹⁴ ENTITE (au sens de « base d'un accord »), ABSTRAIT (au sens de « éléments, circonstances qui déterminent une situation »), mais aussi ESPACE (« Lieu où l'on pratique le conditionnement d'un textile »).

Or, ce dernier sens est spécialisé et il ne correspond à aucune signification du OHFD. Le manque de distinction entre le vocabulaire général et spécialisé, ainsi que l'incohérence entre AlethDic et OHFD sur ce sujet, est source d'erreur lors de l'application des règles sémantiques.

D'autre part, on retrouve, comme dans le cas de l'utilisation de WordNet, le problème de classes trop générales qui élargissent excessivement la portée des règles sémantiques. Par exemple, la classe ABSTRAIT, à laquelle appartiennent *style* et *dieu*, recouvre l'« ensemble des notions universellement reconnues ». En contexte, on pourra donc obtenir des erreurs de confusion dues à une généralisation excessive. Dans la phrase :

Ils nous demandaient : « C'est le soleil ou c'est le bon Dieu ? »

le mot *bon* sera fautivement désambiguïsé par la règle :

bon_(I.1,I.2,I.3,I.4,I.5,I.6,I.7,I.8,I.9,I.10,I.11,I.12,II.1,III.1,III.2,III.3,IV.1,V.1)
ADJ(bon,ABSTRAIT) => II.2

qui est la règle sémantique correspondant à la règle lexicale :

bon_(I.1,I.2,I.3,I.4,I.5,I.6,I.7,I.8,I.9,I.10,I.11,I.12,II.1,III.1,III.2,III.3,IV.1,V.1)
ADJ(bon,style) => II.2

Or, le sens désigné par cette règle de désambiguïsation correspond au sens « de qualité » alors que « bienveillant » aurait été plus indiqué. Cette erreur vient du fait que selon AlethDic, *dieu* et *style* sont sémantiquement équivalents de par leur classe ABSTRAIT.

Il ne faudrait pas en conclure qu'AlethDic soit meilleur que WordNet, ou l'inverse : c'est la cohérence entre ressources dictionnaire et thésaurique qui importe (cf. infra). Ce problème de cohérence est d'ailleurs probablement mis en exergue par la granularité plus fine des classes sémantiques utilisées dans le cas du français.

2) La couverture globale (.35) est à peu près semblable à celle que nous obtenions dans le cas de l'anglais (qui était de .37), ce qui est relativement étonnant puisque, ne disposant que des classes sémantiques pour les noms et quelques adjectifs et adverbes en français, le nombre de règles sémantiques extraites dans le cas du français est bien inférieur à celui de l'anglais (86 400 règles sémantiques en français contre 132 000 en anglais). Il semble que la couverture des règles lexicales en français soit nettement supérieure à celle de l'anglais, en particulier pour les noms, peut-être est-ce dû à la nature des corpus d'évaluation¹⁵.

14. Cf. définitions libres AlethDic.

15. HECTOR (cf. SensEval) pour l'anglais, *Le Monde* pour le français.

3) Dans les deux cas, la couverture est relativement faible. Une première remarque que nous pouvons faire est que l'extraction des règles est loin de couvrir la totalité des mots du dictionnaire. Le tableau 2 récapitule quelques chiffres concernant le dictionnaire et les règles extraites.

	Nombre total d'entrées en français	Nombre d'entrées pour lesquelles au moins une règle est extraite	Nombre moyen de règles par mots
français	38 944	15 224	14.3
anglais	47 539	16 091	16.8

Tableau 2 – Quelques données numériques associées au dictionnaire

Pour bien des entrées lexicales, ni exemples ni collocations ne sont attachées aux différents sens des mots, et nous ne pouvons donc pas en extraire de règles. Le dictionnaire OHFD est en effet construit pour des utilisateurs humains et bien souvent un indicateur ou une étiquette sémantique est suffisant pour caractériser un sens donné.

4.2. Perspectives

La méthodologie employée a montré de bons résultats pour l'anglais et des résultats un peu moins bons mais néanmoins intéressants dans le cas du français : nous sommes à présent tout à fait convaincus de l'intérêt de l'utilisation de l'information d'un dictionnaire ainsi que du contexte syntaxique dans le cadre de la tâche de désambiguïsation. En outre, cette méthode a l'avantage de ne pas nécessiter de corpus d'apprentissage, contrairement aux méthodes statistiques par exemple : le dictionnaire fait office de corpus sémantiquement étiqueté tout en n'étant pas cantonné à ce rôle puisqu'ayant bien d'autres usages possibles.

Cependant la méthode présente un certain nombre de problèmes liés à la cohérence entre informations du dictionnaire et informations sémantiques des thesaurus. Elle présente aussi un problème en termes de couverture puisque celle-ci est relativement limitée. Nous avons plusieurs idées qui nous semblent intéressantes pour essayer de pallier ces différents problèmes.

Partons d'un exemple qui montre le besoin d'améliorer la cohérence entre ressource lexicale et classes sémantiques. Afin de désambiguïser *assumer* dans la phrase suivante :

*Il s'agit aussi d'**assumer** une mission pédagogique vis-à-vis de l'opinion, mission que je crois essentielle, aujourd'hui, compte tenu de la complexité des problèmes.*

le système applique la règle suivante :

assumer_{I.1,I.2} DOBJ(assumer,ABSTRAIT/ENTITE/ESPACE/ETAT)=> I.2

Cette règle est construite en utilisant la collocation objet du sens I.2 de *assumer* à savoir *assumer sa condition*. Elle pointe sur le sens *accepter* de l'entrée alors que *prendre en charge* (I.1) aurait été plus indiqué dans ce contexte.

Les mots *condition* et *mission* possèdent en commun les classes ENTITE (décrivant les objets abstraits) et ESPACE (comprenant les lieux aménagés), et de ce fait le système les a rapprochés. D'une part, ENTITE est une classe extrêmement générale. De l'autre, ESPACE recouvre une acception spécialisée de *condition* (lieu où l'on pratique le conditionnement d'un textile), qui est absente du OHFD ; quant à l'acception de *mission* en tant que lieu dans le OHFD, elle est spécifiée par une étiquette *religieux*, en association avec d'autres significations (*charge, organisation*), membres de la classe ENTITE. On retrouve aussi le même genre de problème dans le cas de l'anglais, les recoupements entre le OHFD et WordNet n'étant pas toujours cohérents.

Afin d'améliorer le système nous pensons qu'il serait intéressant d'utiliser le dictionnaire lui-même comme ressource sémantique. Voici les trois entrées lexicales (racourcies) mises en jeu dans l'exemple précédent :

mission : /misjO+ / nf

- I.1 (tâche) mission, task ; ...
- I.2 (fonction temporaire) mission, assignment ; ...
- I.3 (groupe) mission, team ; ...
- I.4 Mil (but) mission ;
- I.5 Relig (charge, organisation, bâtiment) mission ; ...

assumer /asyme/ vtr

- I.1 (prendre en charge) to take [responsabilité] ; to hold [fonctions] ; ...
- I.2 (accepter) to come to terms with [condition, identité, passé] ;

responsabilité/KEspO+ sabilite/ nf

- I.1 (participation) gén responsibility ;
- I.2 (charge) responsibility ;
- I.3 (fait de devoir répondre de ses actions) responsibility ;
- I.4 Assur liability ; civile personal liability.

Si l'on pouvait associer de manière cohérente une classification sémantique à chacun des sens du dictionnaire, nous pourrions disposer d'une base de règles cohérente et également beaucoup plus générale que celle dont nous disposons à l'heure actuelle. En

utilisant les indicateurs et les étiquettes sémantiques (dont un traitement spécifique est également réalisé dans le cadre du projet DEFI [MIC 00]), nous pourrions envisager de trouver des classes sémantiques générales valides sur la totalité du dictionnaire.

Par exemple, si nous ajoutons des classes sémantiques caractérisant les différents S2 aux entrées précédentes, indiquées par <csem> ... </csem>, nous obtenons les entrées « augmentées » suivantes :

mission : /misjO+ / nf

- I.1 <csem>rôle</csem> (tâche) mission, task ; ...
- I.2 <csem>fonction</csem> (fonction temporaire) mission, assignment ; ...
- I.3 <csem>groupe</csem> (groupe) mission, team ; ...
- I.4 <csem>militaire</csem> Mil (but) mission ;
- I.5 <csem>religieux</csem> Relig (charge, organisation, bâtiment) mission ; ...

assumer /asyme/ vtr

- I.1 <csem>s'occuper</csem>(prendre en charge) to take [responsabilité] ; to hold [fonctions] ; ...
- I.2 <csem>accepter</csem> (accepter) to come to terms with [condition, identité, passé] ;

responsabilité/KEspO+ sabilite/ nf

- I.1 <csem>morale</csem>(participation) gén responsibility ;
- I.2 <csem>rôle</csem>(charge) responsibility ;
- I.3 <csem>juridique</csem>(fait de devoir répondre de ses actions) responsibility ;
- I.4 <csem>assurance</csem> Assur liability ; civile personal liability.

Nous pouvons alors créer les règles suivantes pour le sens I.1 de *assumer*

$\text{assumer}_{I.1, I.2} \text{ DOBJ}(\text{assumer}, \text{responsabilité}) \Rightarrow \text{I.1}$
 $\text{assumer}_{I.1, I.2} \text{ DOBJ}(\text{assumer}, \text{morale/rôle/juridique/assurance}) \Rightarrow \text{I.1}$

Ces règles nous permettent de désambigüiser *assumer*, et en particulier de retrouver le sens I.1 dans le contexte de notre exemple, le complément d'objet *mission* ayant *rôle* pour classe sémantique.

On peut aussi créer un nouveau type de règle plus général, basé uniquement sur les classes sémantiques attachées aux sens des entrées :

$V_{s'occuper, accepter} \text{ DOBJ}(V, \text{morale/rôle/juridique/assurance}) \Rightarrow s'occuper$

Ce qui peut être paraphrasé ainsi : si un verbe, ambigu entre les classes *s'occuper* et *accepter*, a pour complément d'objet direct un mot ambigu entre les classes *morale*, *rôle*, *juridique*, et *assurance*, alors il peut être désambiguïsé avec son sens *s'occuper*.

Les étiquettes sémantiques nous paraissent être des sources d'informations qu'il serait valable d'exploiter afin de dériver une hiérarchie sémantique du dictionnaire. Par exemple, on trouve dans le OHFD les indicateurs suivants : *garçon*, *fille*, *homme laid*, *vieille femme*, *homme préhistorique* ..., qui pourraient constituer les feuilles d'une ontologie spécifiant la classe *humain*. Cette hiérarchie serait certainement bénéfique à l'amélioration et à la généralisation de notre application. Nous sommes conscients de la difficulté d'une telle tâche dont la méthodologie reste à élaborer. La conception d'un jeu d'étiquettes cohérent couvrant l'ensemble du dictionnaire constitue un sujet de recherche à part entière. L'automatisation complète d'un tel processus s'est d'ailleurs déjà révélée problématique : l'extraction automatique de larges bases de connaissances à partir de dictionnaires ([CHO 85, KLA 90, WIL 90, IDE 95]) n'a jamais complètement abouti. Il semble a priori qu'une phase de validation, voire d'enrichissement manuel soit nécessaire, mais cet effort nous semble justifié compte tenu de la qualité de la ressource lexicale que l'on obtiendrait et de son utilité dans le cadre d'applications de TAL.

5. Conclusion

Cet article présente un système de désambiguïsation lexicale sémantique s'appuyant sur l'utilisation d'un dictionnaire électronique. Le système extrait une fois pour toutes une base de règles de désambiguïsation du dictionnaire ; ces règles sont par la suite utilisées pour désambiguïser des mots dans des textes de nature quelconque. Ce système présente différents avantages : l'utilisation du dictionnaire évite de recourir à des corpus sémantiquement étiquetés, très difficiles à obtenir ; les informations exploitées sont fiables dans la mesure où elles sont validées par des lexicographes ; le contexte syntaxique s'avère également très utile pour la désambiguïsation ; la taille des données traitées est transparente pour le système, dans la mesure où le contexte utilisé pour la désambiguïsation ne dépasse pas une phrase.

Cependant, un certain nombre de problèmes sont mis en évidence dans la phase d'évaluation. Si les règles lexicales offrent une très grande précision, celle-ci doit être améliorée pour les règles sémantiques. Une amélioration de la couverture du système serait également la bienvenue.

Plusieurs axes de recherche sont envisagés. Nous pensons tout d'abord modifier le système afin d'y intégrer un analyseur syntaxique plus élaboré, XIP¹⁶, qui permettrait d'encoder dans les relations syntaxiques plus d'informations sur le contexte, par exemple la nature du déterminant introduisant un groupe nominal (par exemple *abandonner* [+Humain] à [+Possessif] [ADJ] sort).

16. En cours d'implantation à XRCE.

Ensuite, les règles de désambiguïsation conservent les classes d'ambiguïtés des arguments des relations. Mais dans un exemple du dictionnaire comme *abandonner un lieu*, l'argument, ici le mot *lieu*, appartient à une classe donnée (dans ce cas ESPACE_LOCATIF selon AlethDic, et non ENTITE ou ANIMAL). Si nous parvenions à isoler la classe sémantique des arguments dans le contexte donné par le dictionnaire, la précision des règles serait très largement accrue.

Enfin, l'amélioration du système passe par une plus grande cohérence entre les ressources sémantiques et le dictionnaire : il nous semble très intéressant d'utiliser le dictionnaire lui-même comme ressource sémantique afin de construire une base de connaissances sémantiques. Une telle ressource aurait plusieurs avantages dans le cadre de l'application visée : elle offrirait un meilleur recouvrement des sens dans les règles et permettrait un élargissement de la portée de celles-ci. En effet, nous pourrions créer des règles additionnelles désambiguïsant non plus des mots mais des classes de mots en fonction du contexte.

D'une manière générale, ce système a de nombreuses applications : nous l'utilisons déjà dans un système d'aide à la compréhension de textes écrits dans des langues étrangères. L'intégrer dans des processus d'indexation sémantique et plus généralement dans tout type d'application visant à l'extraction et la compréhension de connaissances contenues dans des documents électroniques nous semble particulièrement prometteuse.

Remerciements

Nous tenons tout particulièrement à remercier chaleureusement Agnès Sandor pour son travail sur l'évaluation du système, ainsi que pour sa relecture attentive de cet article.

6. Bibliographie

- [AKR 92] AKROYD R., « Markup for the Oxford-Hachette French dictionary », Rapport technique, septembre 1992, Oxford University Press.
- [AïT 97] AïT-MOKHTAR S., CHANOD J.-P., « Subject and Object Dependency Extraction Using Finite-State Transducers. », *Actes du Workshop on automatic Information Extraction and the Building of Lexical Semantic Resources, ACL*, Madrid, Espagne, 1997, p. 71-77.
- [BRU 00] BRUN C., « A Client/Server Architecture for Word Sense Disambiguation », *Actes de la 18th International Conference on Computational Linguistics (COLING'2000)*, Saarbrücken, Allemagne, 31 juillet - 4 août 2000, p. 132-138.
- [BRU 01] BRUN C., SEGOND F., « Semantic encoding of electronic documents », *International Journal of Corpus Linguistics*, vol. 6, n° 1, 2001, à paraître.
- [CAR 00] CARROLL J., MCCARTHY D., « Word Sense Disambiguation Using Automatically Acquired Verbal Preferences », *Computer and the Humanities*, vol. 34, n° 1-2, avril 2000, p. 109-114.

- [CHO 85] CHODORROW M., BYRD R. J., E. HEIDORN G., « Extracting semantic hierarchies from a large on-line dictionary », *Proceedings of the 23rd Annual Meeting of the Association for Computational Linguistics*, Chicago, 1985, p. 299-304.
- [COR 94] CORRÉARD M.-H., GRUNDY V., Eds., *Oxford-Hachette French Dictionary*, Oxford-Hachette, Paris, 1994.
- [COW 92] COWIE J., GUTHRIE J. A., GUTHRIE L., « Lexical Disambiguation using simulated annealing », *Proceedings of the International Conference of Computational Linguistics, COLING'92*, Nantes, France, 23-28 août 1992, p. 359-365.
- [DIN 98] DINI L., DI-TOMASO V., SEGOND F., « Error Driven Word Sense Disambiguation », *Actes de COLING/ACL98*, Montréal, Canada, 1998, p. 320-324.
- [DIN 00] DINI L., DI-TOMASO V., SEGOND F., « GINGER II : an example-driven word sense disambiguator », *Computer and the Humanities, special issue on Senseval*, vol. 34, n° 1-2, April 2000, p. 121-126.
- [ELL 00] ELLMAN J., KLINCKE I., TAIT J., « Word Sense Disambiguation by Information Filtering and Extraction », *Computer and the Humanities*, vol. 34, n° 1-2, avril 2000, p. 127-134.
- [FEL 98] FELLBAUM C., *WordNet : An Electronic Lexical Database*, MIT Press, Cambridge (MA), 1998.
- [GENELEX 94] GENELEX C., « Projet EUREKA GENELEX. Rapport sur la couche sémantique », ASSTRIL, Gsi-Erli, IBM France, SEMA GROUP, 2.1 édition, 30 septembre 1994.
- [Gsi94] Gsi Erli, France, « Le dictionnaire AlethDic », 1.5.4 édition, 15 décembre 1994.
- [GUT 91] GUTHRIE J. A., GUTHRIE L., WILKS Y., AIDINEJAD H., « Subject-dependent co-occurrence and word sense disambiguation », *Proceedings of the 29th Annual Meeting of the Association for Computational Linguistics*, Berkeley, Californie, États-Unis, 18-21 juin 1991, p. 146-152.
- [HAW 00] HAWKINS P., NETTLETON D., « Large Scale WSD Using Learning Applied to SENSEVAL », *Computer and the Humanities*, vol. 34, n° 1-2, avril 2000, p. 135-140.
- [IDE 95] IDE N., VÉRONIS J., « Knowledge extraction from machine-readable dictionaries : an evaluation », In P. Steffens (Ed.), *Machine Translation and the Lexicon*, Berlin, 1995, p. 19-34.
- [IDE 98] IDE N., VÉRONIS J., « Introduction to the Special Issue on Word Sense Disambiguation : The State of the Art », *Computational Linguistics*, vol. 24, n° 1, 1998.
- [KIL 98] KILGARRIFF A., « SENSEVAL : An Exercise in Evaluating Word Sense Disambiguation Programs », *Actes de First International Conference on Language Resources and Evaluation*, Grenada, Spain, 1998, p. 581-585.
- [KIL 99] KILGARRIFF A., « Gold standard datasets for evaluating word sense disambiguation programs », *Computer and the Humanities*, vol. 33, n° 2, 1999.
- [KLA 90] KLAVANS J., CHODORROW M., WACHHOLDER N., « From dictionary to knowledge base via taxonomy », *Actes de 6th conference of the UW centre for the new OED*, Waterloo, Canada, 1990, p. 110-132.
- [LES 86] LESK M., « Automated Sense Disambiguation Using Machine-readable Dictionaries : How to Tell a Pine Cone from an One Cream Cone », *Proceedings of the 1986 SIGDOC Conference*, Toronto, Canada, June 1986, p. 24-26.
- [LIT 00] LITKOWSKI K. C., « Senseval : The CL Research Experience », *Computer and the Humanities*, vol. 34, n° 1-2, avril 2000, p. 153-158.

- [LUX 99] LUX V., JEAN C., SEGOND F., « WSD evaluation and the looking glass », *Actes TALN 99*, Cargèse, Corse, juillet 1999.
- [MEN 93] MENON B., MODIANO N., « Eagles. Lexicon Architecture », rapport, octobre 1993.
- [MIC 00] MICHIELS A., « New Developments in the DEFI Matcher », *International Journal of Lexicography*, vol. 13, n° 3, 2000, p. 151-168.
- [PRO 78] PROCTER P., ILSON R., Eds., *Longman dictionary of contemporary English*, Longman Harlow, Essex, 1978.
- [RES 95] RESNIK P., « Disambiguating Noun Groupings with Respect to WordNet Senses », *Proceedings of the Third Workshop on Very Large Corpora*, Cambridge, Massachusetts, USA, 1995, p. 54-68.
- [SEG 97] SEGOND F., SCHILLER A., GREFENSTETTE G., CHANOD J.-P., « An Experiment in Semantic Tagging using Hidden Markov Model Tagging », *Actes du ACL-EACL Workshop about lexical semantic*, Madrid, 1997, p. 78-81.
- [SEG 00a] SEGOND F., « Framework and Results for French », *Computer and the Humanities, special issue on Senseval*, vol. 34, n° 1-2, April 2000, p. 40-60.
- [SEG 00b] SEGOND F., AIMELET E., LUX V., « Dictionary-driven semantic look-up », *Computer and the Humanities, Special Issue on SENSEVAL*, vol. 34, n° 1-2, 2000, p. 193-197.
- [SUS 93] SUSSNA M., « Word Sense Disambiguation for Free-text Indexing Using a Massive Semantic Network », *Proceedings of the Second International Conference on Information and Knowledge Base Management, CIKM'93*, Arlington, Virginie, E-U, 1993, p. 67-74.
- [VIE 99] VIEGAS E., « The Manifesto of Large-scale Semantic Lexicon Acquisition », *Traitement Automatique des Langues, Special Issue on Multilingual Processing*, vol. 40, n° 1, 1999, p. 27-53.
- [VÉR 90] VÉRONIS J., IDE N., « Word Sense Disambiguation with Very Large Neural Networks Extracted from Machine Readable Dictionaries », *13th International Conference on Computational Linguistics COLING'90*, Helsinki, Finland, 1990, p. 389-394.
- [VÉR 98a] VÉRONIS J., « A study of polysemy judgements and inter-annotator agreement », *Programme and Advanced Papers of Senseval Workshop*, Herstmonceux Castle, England, 1998, p. 2-4.
- [VÉR 98b] VÉRONIS J., IDE N., « Introduction to the Special Issue on Word Sense Disambiguation : The State of the Art », *Computational Linguistics*, vol. 24, n° 1, 1998.
- [WIL 90] WILKS Y., FASS D., GUO C.-M., MACDONALD J. E., PLATE T., SLATOR B. A., « Providing Machine Tractable Dictionary Tools », PUSTEJOVSKI J., Ed., *Semantics and the Lexicon*, MIT Press, 1990.
- [WIL 98] WILKS Y., STEVENSON M., « Word Sense Disambiguation using Optimised Combinations of Knowledge Sources », *Actes de COLING/ACL98*, Montréal, Canada, 1998, p. 1398-1403.
- [YAR 95] YAROWSKY D., « Unsupervised word sense disambiguation method rivalizing supervised methods », *Actes de ACL 95*, Cambridge, Massachusetts, 1995, p. 189-196.